4B

УДК 681.322

Д.А. Вятченин, В.В. Старовойтов
Объединенный институт проблем информатики НАН Беларуси, г. Минск
viattchenin@mail.ru

Идентификация объектов посредством системы нечеткого вывода

В статье предлагается методология идентификации объектов на аэрокосмических изображениях в режиме времени, близком к реальному, посредством механизма нечеткого вывода на примере системы нечеткого вывода типа Мамдани. Кратко излагается метод быстрого прототипирования системы нечеткого вывода на основе результатов обработки данных об объектах обучающей выборки эвристическим алгоритмом возможностной кластеризации. Приводятся результаты вычислительных экспериментов и сформулированы предварительные выводы.

Введение

В задачах обработки и анализа аэрокосмических изображений особое место занимают методы идентификации обнаруженных на снимках объектов, то есть методы отнесения того или иного объекта к одному из нескольких заданных классов. Следует указать, что в ряде задач, таких, к примеру, как поддержание в актуальном состоянии кадастровых карт, мониторинге земной поверхности в целях обнаружения чрезвычайных ситуаций, а также при разработке систем специального назначения, обнаружение и идентификация объектов заданных классов должна производиться в реальном режиме времени. Для решения задачи идентификации объектов традиционно используются, с одной стороны, нейросетевые модели, а с другой – продукционные модели.

В условиях неточной, нечеткой и неопределенной информации представляется целесообразным обращение к нечетким моделям, что позволяет получить, с одной стороны, точные, а с другой – содержательно осмысленные результаты идентификации объектов.

Целью данной работы является разработка общей схемы применения системы нечеткого вывода типа Мамдани [1], генерируемой на основе результатов обработки данных об объектах обучающей выборки D-AFC(c)-алгоритмом возможностной кластеризации [2], предусматривающей возможность дообучения соответствующей системы в процессе распознавания объектов на аэрокосмических снимках.

Методы построения базы правил системы нечеткого вывода, основанные на нечеткой кластеризации

Системы нечеткого вывода представляют собой алгоритм получения нечетких заключений на основе нечетких предпосылок [3]. Главным элементом систем нечеткого вывода является база нечетких продукционных правил, в наиболее общем случае имеющих вид

l: ЕСЛИ $€^1$ есть B_l^1 И … И $€^m$ есть B_l^m ТО y_1 есть C_1^l И … И y_c есть C_c^l, (1)

где $l \in \{1,\ldots,c\}$ – номер правила, $€^t \in X^t$, $t \in \{1,\ldots,m\}$ – входные переменные и X^t – область определения соответствующей переменной, $y_l \in Y_l$, $l \in \{1,\ldots,c\}$ – нечеткие

выходные переменные, причем Y_l – область определения соответствующего заключения, а B_l^t, C_l^l – нечеткие множества с функциями принадлежности $\gamma_{B_l^t}(\text{€}^t)$ и $\gamma_{C_l^l}(y_l)$, определенные на соответствующих универсумах. В правиле вида (1) m предпосылкам соответствует c заключений, в силу чего структура такого правила в специальной литературе именуется MIMO-структурой [3].

База нечетких правил, являющаяся основным элементом системы нечеткого вывода, может формироваться, с одной стороны, экспертным путем, а с другой – на основе обработки данных обучающей выборки, для чего чаще всего используются оптимизационные методы нечеткой или возможностной кластеризации [4]. При втором подходе исследуемая совокупность $X = \{x_1, \ldots, x_n\}$ объектов обучающей выборки обрабатывается каким-либо методом нечеткой или возможностной кластеризации с последующим проецированием значений принадлежности μ_{li}, или значений типичности υ_{li} того или иного нечеткого кластера A^l, $l = 1, \ldots, c$ на координатные оси признакового пространства $I^m(X)$. Полученные таким образом нечеткие множества с дискретными функциями принадлежности $\tilde{\gamma}_{B_l^t}(\text{€}^t)$ аппроксимируются параметрическими непрерывными функциями принадлежности $\gamma_{B_l^t}(\text{€}^t)$ – как правило, треугольной или трапецевидной формы – для чего целесообразно воспользоваться алгоритмом, предложенным в [5] М. Сугэно и Т. Ясукавой.

Так как в оптимизационных методах нечеткой и возможностной кластеризации первоначальное разбиение формируется случайным образом, то для получения приемлемого результата классификации в виде нечеткого c-разбиения или возможностного разбиения, необходимым является проведение серии вычислительных экспериментов, что значительно затрудняет, или делает вообще невозможным генерирование базы нечетких правил в реальном режиме времени, или, по крайней мере, в режиме, близком к реальному. Указанного недостатка лишен предложенный в [6] метод проектирования систем нечеткого вывода, основанный на обработке данных об объектах обучающей выборки эвристическим D-AFC(c)-алгоритмом возможностной кластеризации [2], результатом работы которого является так называемое распределение $R^*(X) = \{A^1_{(\alpha)}, \ldots, A^c_{(\alpha)}\}$ объектов совокупности X по заданному числу c частично или полностью разделенных нечетких α-кластеров, которое представляет собой частный случай возможностного разбиения [7], а также соответствующее значение порога сходства α. Основные понятия и схема D-AFC(c)-алгоритма изложены в [2], [8], [9].

Предложенный в [6] метод извлечения нечетких правил, основанный на обработке данных обучающей выборки, представленных матрицей «объект-признак» $X_{n\times m} = [\text{€}_i^t]$, $i = 1, \ldots, n$, $t = 1, \ldots, m$, где n – число объектов классифицируемого множества $X = \{x_1, \ldots, x_n\}$, а m – размерность признакового пространства, с помощью D-AFC(c)-алгоритма, заключается в следующем. Нечеткие множества B_l^t, $l \in \{1, \ldots, c\}$, $t \in \{1, \ldots, m\}$ предпосылок продукционных правил вида (1) с, в общем случае, трапецевидными функциями принадлежности $\gamma_{B_l^t}(\text{€}^t)$ могут быть представлены в параметрической форме $B_l^t = (\underline{a}^t_{(l)}, \underline{m}^t_{(l)}, \overline{m}^t_{(l)}, \overline{a}^t_{(l)})$, где $\underline{m}^t_{(l)}$ – нижнее модальное значение нечеткого интервала B_l^t, $\overline{m}^t_{(l)}$ – его верхнее модальное значение, а величины $(\underline{m}^t_{(l)} - \underline{a}^t_{(l)})$ и $(\overline{a}^t_{(l)} - \overline{m}^t_{(l)})$ представляют собой значения левого и правого коэффи-

циентов нечеткости соответственно [10]. Необходимо отметить, что в случае совпадения нижнего и верхнего модальных значений, $m_{(l)}^t = \underline{m}_{(l)}^t = \overline{m}_{(l)}^t$, нечеткий интервал B_l^t предпосылки продукционного правила, изображенный на рис. 1 а), будет представлять собой треугольное нечеткое число $B_l^t = (\underline{a}_{(l)}^t, m_{(l)}^t, \overline{a}_{(l)}^t)$ [10]. При построении условных частей нечетких правил задача заключается в определении соответствующих параметров нечетких множеств B_l^t, $l \in \{1,\dots,c\}$, $t \in \{1,\dots,m\}$.

После предварительной обработки матрицы исходных данных $X_{n\times m} = [\tilde{x}_i^t]$, $i = 1,\dots,n$, $t = 1,\dots,m$, заключающейся в нормировке значений $\tilde{x}_i^t$, к примеру, с помощью нормализации

$$x_i^t = \frac{\tilde{x}_i^t}{\max\limits_i \tilde{x}_i^t}, \tag{2}$$

так что каждая строка x_i^t матрицы $X_{n\times m} = [x_i^t]$, $i = 1,\dots,n$, $t = 1,\dots,m$ может интерпретироваться как нечеткое множество на универсуме признаков с соответствующей функцией принадлежности $x_i^t = \mu_{x_i}(x^t) \in [0,1]$, $i = 1,\dots,n$, $t = 1,\dots,m$, и применением к полученному множеству n нечетких множеств какого-либо расстояния между нечеткими множествами [11] – например, квадрата нормализованного евклидова расстояния

$$\varepsilon(x_i, x_j) = \frac{1}{m}\sum_{t=1}^{m}\left(\mu_{x_i}(x^t) - \mu_{x_j}(x^t)\right)^2, \tag{3}$$

получается матрица нечеткого отношения несходства $I = [\mu_I(x_i, x_j)]$, $i, j = 1,\dots,n$, применяя к которой, в свою очередь, операцию дополнения

$$\mu_T(x_i, x_j) = 1 - \mu_I(x_i, x_j),\ \forall i, j = 1,\dots,n, \tag{4}$$

строится матрица нечеткой толерантности $T = [\mu_T(x_i, x_j)]$, $i, j = 1,\dots,n$, на универсуме $X = \{x_1,\dots,x_n\}$.

Для построения базы правил системы нечеткого вывода типа Мамдани [1] данные об объектах исследуемой совокупности, представленные в форме матрицы нечеткой толерантности $T = [\mu_T(x_i, x_j)]$, $i, j = 1,\dots,n$ обрабатываются D-AFC(c)-алгоритмом для заданного числа классов c, и для каждого нечеткого α-кластера $A_{(\alpha)}^l$, $l \in \{1,\dots,c\}$ полученного распределения $R^*(X) = \{A_{(\alpha)}^1,\dots,A_{(\alpha)}^c\}$ выделяется его ядро $K(A_{(\alpha)}^l)$ и носитель A_α^l. Кроме того, как указывалось выше, дополнительным результатом классификации является значение порога сходства $\alpha \in (0,1]$, соответствующего полученному результату классификации $R^*(X)$. Интервал $[\tilde{x}_{(l)\min}^t, \tilde{x}_{(l)\max}^t]$ значений каждого признака $\tilde{x}^t$, $t \in \{1,\dots,m\}$ вычисляется для носителя A_α^l каждого нечеткого α-кластера $A_{(\alpha)}^l$, $l \in \{1,\dots,c\}$. В частности, значение $\tilde{x}_{(l)\min}^t$, $t \in \{1,\dots,m\}$ может быть получено по формуле

$$\tilde{x}_{(l)\min}^t = \min_{x_i \in A_\alpha^l} \tilde{x}^t,\ \forall t \in \{1,\dots,m\},\ \forall l \in \{1,\dots,c\}, \tag{5}$$

а значение $\tilde{x}_{(l)\max}^t$, $t \in \{1,\dots,m\}$ – по формуле

$$\tilde{x}_{(l)\max}^t = \max_{x_i \in A_\alpha^l} \tilde{x}^t,\ \forall t \in \{1,\dots,m\},\ \forall l \in \{1,\dots,c\}. \tag{6}$$

В свою очередь, параметр $\underline{a}^t_{(l)}$ вычисляется путем решения линейных уравнений при условиях

$$\gamma_{B^t_l}(€^t_{(l)\min}) = (1-\alpha)\,,\ \gamma_{B^t_l}(\underline{a}^t_{(l)}) = 0\,, \tag{7}$$

а параметр $\overline{a}^t_{(l)}$ – при условиях

$$\gamma_{B^t_l}(€^t_{(l)\max}) = (1-\alpha)\,,\ \gamma_{B^t_l}(\overline{a}^t_{(l)}) = 0\,. \tag{8}$$

Значение $\underline{€}^t_{(l)}$ вычисляется для всех типичных точек $\tau^l_e \in K(A^l_{(\alpha)})$ нечеткого α-кластера $A^l_{(\alpha)}$, $l \in \{1,\ldots,c\}$ в соответствии с выражением

$$\underline{€}^t_{(l)} = \min_{\tau^l_e \in K(A^l_{(\alpha)})} €^t\,,\ \forall e \in \{1,\ldots,|l|\}\,, \tag{9}$$

а значение $\overline{€}^t_{(l)}$ – по формуле

$$\overline{€}^t_{(l)} = \max_{\tau^l_e \in K(A^l_{(\alpha)})} €^t\,,\ \forall e \in \{1,\ldots,|l|\}\,. \tag{10}$$

Таким образом, параметр $\underline{m}^t_{(l)}$ может быть вычислен путем решения линейных уравнений, исходя из условий

$$\gamma_{B^t_l}(\underline{€}^t_{(l)}) = \gamma_{B^t_l}(\underline{m}^t_{(l)}) = 1\,, \tag{11}$$

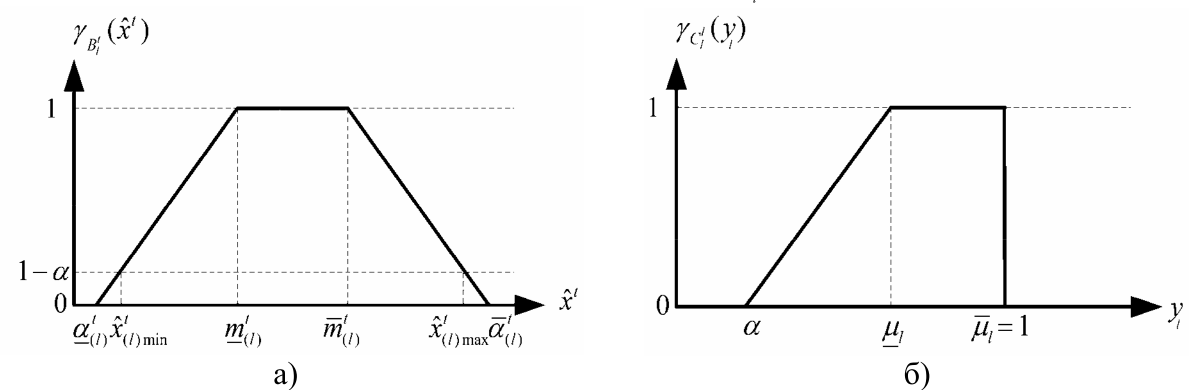
а параметр $\overline{m}^t_{(l)}$ вычисляется аналогичным образом при условиях

$$\gamma_{B^t_l}(\overline{€}^t_{(l)}) = \gamma_{B^t_l}(\overline{m}^t_{(l)}) = 1\,. \tag{12}$$

Таким образом, число входных переменных $€^t$ генерируемых правил вида (1) соответствует размерности признакового пространства $I^m(X)$, а число выходных переменных y_l, которым в соответствие могут быть поставлены метки классов, как и число продукционных правил, эквивалентно числу нечетких α-кластеров $A^l_{(\alpha)}$, $l \in \{1,\ldots,c\}$ полученного распределения $R^*(X)$.

Функции принадлежности заключений нечетких правил целесообразно строить следующим образом: нечеткие множества C^l_l, $l \in \{1,\ldots,c\}$ заключений продукционных правил вида (1) представляются в параметрической форме $C^l_l = (\alpha, \underline{\mu}_l, \overline{\mu}_l, 1)$, где α – порог сходства, при котором строится решение $R^*(X)$ задачи классификации, также являющийся, как указывалось выше, результатом работы D-AFC(c)-алгоритма, $\underline{\mu}_l$ – наименьшее значение принадлежностей объектов $x_i \in A^l_\alpha$ соответствующему нечеткому α-кластеру $A^l_{(\alpha)} \in R^*(X)$, $\underline{\mu}_l = \min_{x_i \in A^l_\alpha} \mu_{li}$, а $\overline{\mu}_l$ – наибольшее значение принадлежности объектов $x_i \in A^l_\alpha$ нечеткому α-кластеру $A^l_{(\alpha)} \in R^*(X)$, $l \in \{1,\ldots,c\}$, $\overline{\mu}_l = \max_{x_i \in A^l_\alpha} \mu_{li}$, причем, если в результате обработки данных D-AFC(c)-алгоритмом полученные нечеткие α-кластеры $A^l_{(\alpha)} \in R^*(X)$, $l \in \{1,\ldots,c\}$ будут являться сильными нечеткими α-кластерами [12], то, очевидно, будет иметь место $\overline{\mu}_l = 1$, так что трапецидная функция принадлежности $\gamma_{C^l_l}(y_l)$ соответствующего нечеткого множества C^l_l, $l \in \{1,\ldots,c\}$ примет вид, изображенный на рис. 1 б). В случае же, когда носитель A^l_α некоторого нечеткого α-кластера $A^l_{(\alpha)}$ построенного распределения $R^*(X)$ пред-

ставляет собой пустое множество, то выходной переменной y_l, $l \in \{1,\ldots,c\}$ будет соответствовать пустое нечеткое множество C_l^l, так что $\gamma_{C_l^l}(y_l) = 0$.



а) б)

Рисунок 1 – Функции принадлежности нечеткого множества:

а) предпосылки; б) заключения

Правила построенной указанным способом базы нечетких продукций будут иметь вид (1) как в случае, когда нечеткие α-кластеры $A_{(\alpha)}^l$, $l \in \{1,\ldots,c\}$ являются частично разделенными, так и в случае полностью разделенных нечетких α-кластеров, причем в случае частично разделенных нечетких α-кластеров, каждой из c условных частей правил (1) будут соответствовать несколько непустых нечетких множеств C_l^l, $l \in \{1,\ldots,c\}$, соответствующих выходным переменным y_l, $l \in \{1,\ldots,c\}$.

Формирование обучающих данных для построения системы нечеткого вывода

Для построения системы нечеткого вывода необходимо подготовить обучающую информацию, характеризующую объекты соответствующих классов. Так как распознаванию подлежат присутствующие на снимках объекты, то процесс подготовки данных для последующей обработки D-AFC(c)-алгоритмом с целью построения системы нечеткого вывода может быть в виде последовательности этапов, представленных в табл. 1.

Таблица 1 – Формирование данных для построения системы нечеткого вывода

Номер и содержание этапа		Методы решения соответствующей задачи
1	Предварительная обработка изображения	Контрастирование, фильтрация и т.п.
2	Локализация области интереса, содержащего объект определенного класса	Интерактивное указание оператором; автоматическое определение
3	Обработка фрагмента изображения	Сегментация изображения
4	Выделение объекта на изображении	Устранение шума; удаление областей, не относящимся к объектам интереса
5	Вычисление характеристик обнаруженного объекта	В зависимости от задачи, конкретизируются геометрические количественные характеристики: длина, периметр и т.д.

При вычислении характеристик объектов следует учитывать, что объекты одного класса могут ориентироваться на изображении различным образом, так что характеристики объектов должны выбираться с учетом данного обстоятельства. К примеру, характеристиками объекта могут служить: длина в пикселях проекции объекта на ось X, длина проекции на ось Y, а также общее число пикселей, составляющих объект интереса, как это изображено на рис. 2.

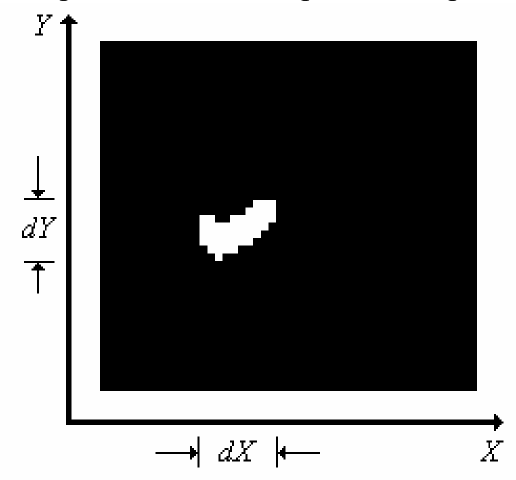


Рисунок 2 – Признаки объекта

Упрощенный пример процесса обнаружения объекта заданного класса на исходном изображении приведен на рис. 3 – так, на рис. 3 а) представлено исходное изображение размерностью 1277×928 пикселей, на рис. 3 б) – интерактивно выделенный фрагмент исходного изображения размерностью 197×183 пикселя, предположительно содержащий объект класса «автомобили», на рис. 3 в) изображен результат сегментации выделенного фрагмента, представляющий собой бинарное изображение, содержащее как связную область, возможно, являющуюся объектом заданного класса, так и другие связные области, и, наконец, на рис. 3 г) представлен результат после удаления шума и исключения других связных объектов – бинарное изображение, определяющее расположение объекта на снимке.

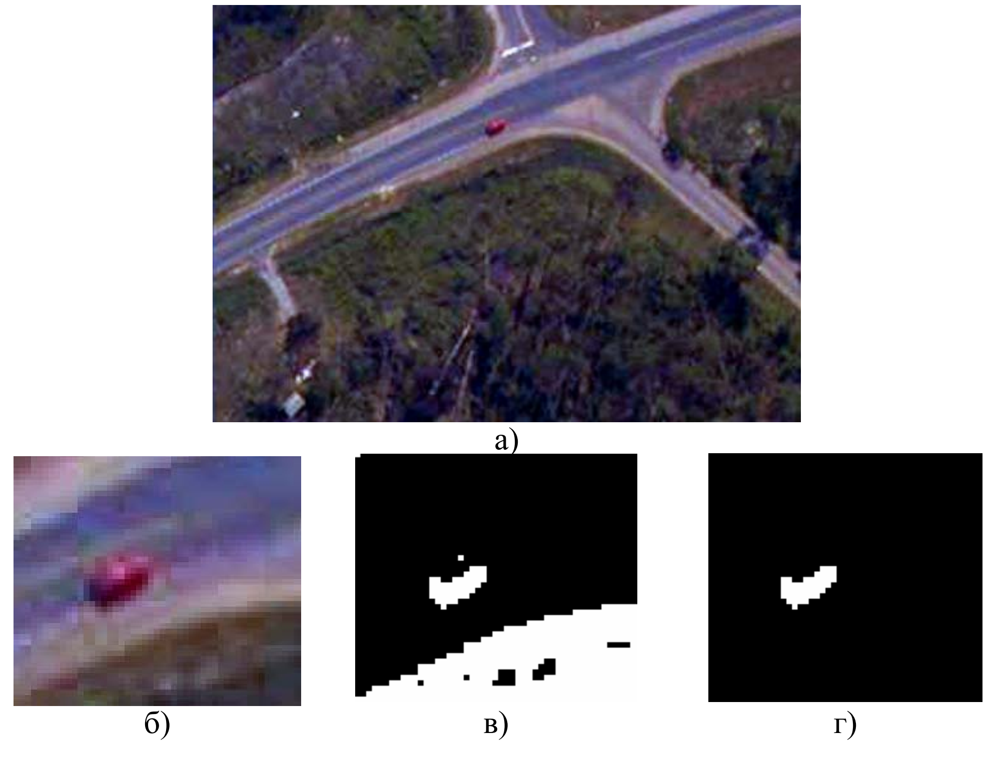


Рисунок 3 – Этапы обнаружения объекта заданного класса на изображении: а) исходное изображение; б) фрагмент изображения; в) бинарное изображение – результат сегментации фрагмента; г) бинарное изображение объекта на фоне

Следует отметить, что для сегментации изображений могут использоваться самые разнообразные подходы, такие, как методы кластеризации, метод управляемого водораздела, а также пороговая сегментация [13]; при этом необходимо указать, что выбор того или иного метода сегментации диктуется условиями конкретной задачи и зависит от особенностей обрабатываемого изображения.

Общая схема применения системы нечеткого вывода для идентификации объектов на изображениях

При идентификации с помощью системы нечеткого вывода вновь поступающих объектов может оказаться, что объект не будет отнесен ни к одному из заданных классов. В такой ситуации система нечеткого вывода должна быть сгенерирована повторно с учетом данных о нераспознанном объекте. Общая схема процесса генерирования системы нечеткого вывода с учетом данных о поступающих на класссификацию объектов изображена на рис. 4.

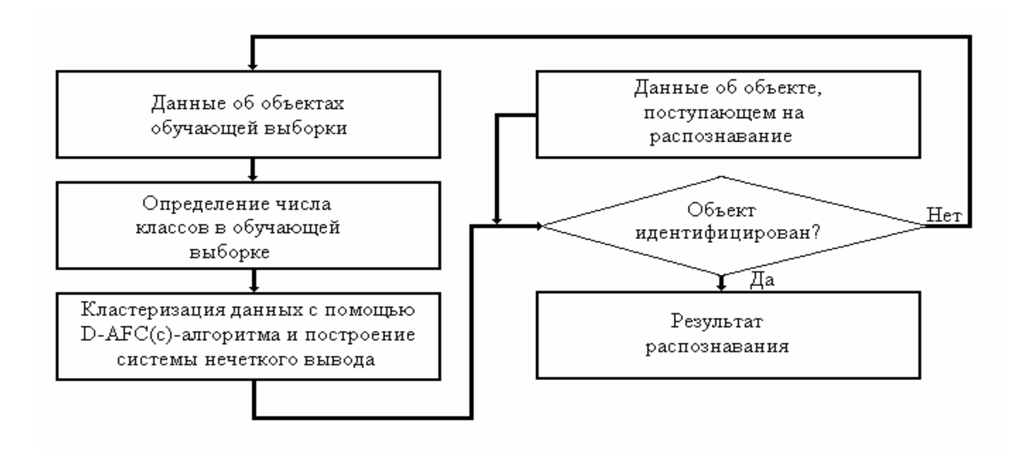


Рисунок 4 – Общая схема дообучения системы нечеткого вывода

На втором шаге представленной выше схемы для определения числа классов, на которое «расслаивается» обучающая выборка, можно использовать любую быструю кластер-процедуру, не требующую априорного задания числа классов c – к примеру, D-AFC-TC-алгоритм возможностной кластеризации [14] или субтрактивный SCM-алгоритм [15]. Следует, однако, учитывать, что при использовании D-AFC-TC-алгоритма вид нормировки исходных данных и вид функции расстояния должен совпадать с нормировкой и расстоянием, используемыми при кластеризации данных D-AFC(c)-алгоритмом в процессе построения системы нечеткого вывода.

Иллюстративный пример

Представляется целесообразным проиллюстрировать сущность предложенной методологии на простом примере. Для проведения вычислительных экспериментов были выбраны 50 фрагментов изображений, на которых представлены 30 объектов класса «автомобили» и 30 объектов, не относящихся к указанному классу, такие, как элементы дорожной инфраструктуры, бассейны, другие сооружения и т.п. Сегментация изображений была выполнена с помощью SCFCM-алгоритма нечеткой кластеризации [16] с последующим выделением α-ядер кластеров полученного нечеткого c-разбиения [17], причем в качестве признакового пространства была выбрана яркость в каждой из компонент цветового пространства RGB.

В качестве признаков распознаваемых объектов были выбраны рассмотренные выше: dX – длина в пикселях проекции объекта на ось X, dY – длина проекции на ось Y, а также $NumPix$ – общее число пикселей, составляющих объект. Исследуемая совокупность была разделена на 2 части – обучающую выборку, включающую изображения 20 автомобилей и 20 других объектов, и тестовую, включающую изображения 10 автомобилей и 10 других объектов. Проекция выбранных для проведения экспериментов данных на плоскость первых двух признаков представлена на рис. 5, где объекты обучающей выборки обозначены символом ○, а объекты тестовой – символом ■.

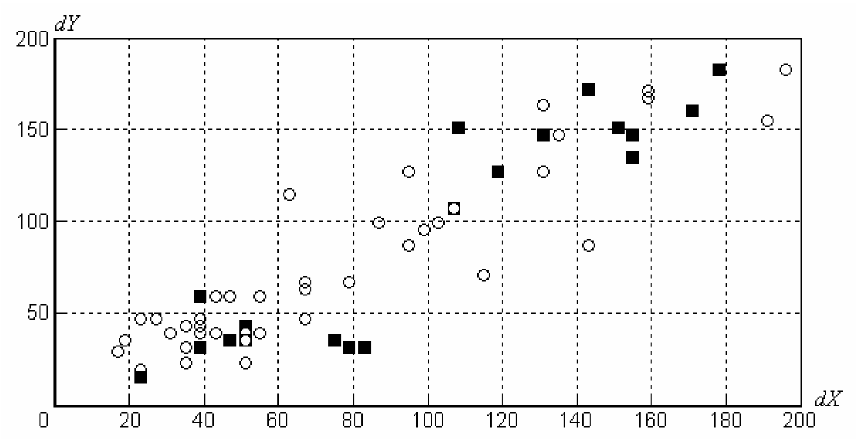


Рисунок 5 – Исходные данные для вычислительных экспериментов

В первом эксперименте с помощью D-AFC-TC-алгоритма [14] возможностной кластеризации с использованием нормализации (2), квадрата нормализованного евклидова расстояния (3) и дополнения (4) были обработаны данные об объектах обучающей выборки, в результате чего число классов, на которые «расслаивается» указанная совокупность, оказалось равным 3. При разбиении данных D-AFC(c)-алгоритмом на 3 класса, также с использованием формул (2), (3) и (4), оказалось, что 4 объекта оказались классифицированными некорректно – объекты, не являющиеся автомобилями, были классифицированы как автомобили. Распределение $R^{*}(X)$ по 3 полностью разделенным нечетким кластерам было получено при значении порога сходства $\alpha = 0{,}9347$. Исходя из результатов кластеризации, была построена система нечеткого вывода, включающая 3 правила. На рис. 6 приведен пример работы построенной системы при идентификации объекта, изображенного на рис. 3 г).

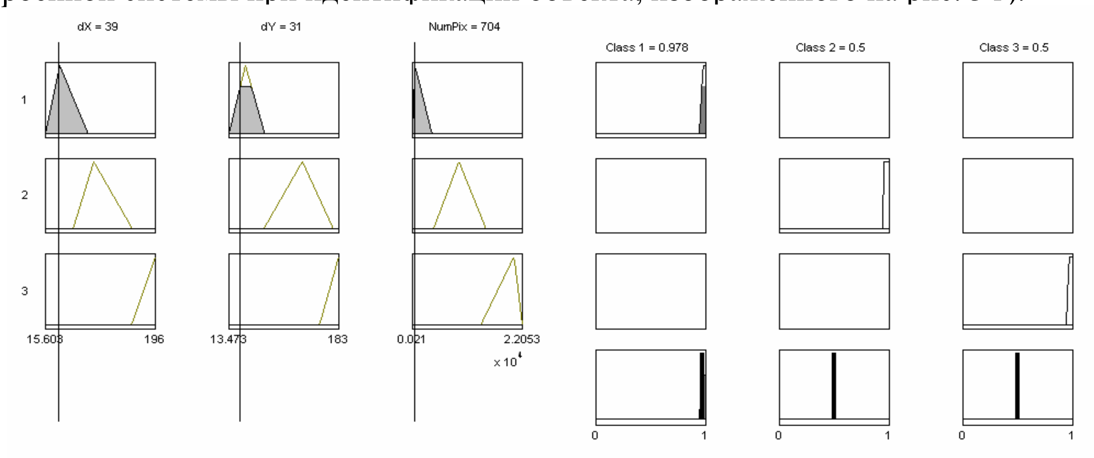


Рисунок 6 – Пример классификации объекта исследуемой совокупности с помощью построенной системы нечеткого вывода типа Мамдани

В процессе распознавания всех 60 объектов некорректно идентифицированными оказались 4 объекта, которые также были некорректно классифицированными при обработке обучающей выборки D-AFC(c)-алгоритмом, и 7 объектов, являющихся элементами тестовой выборки, оказались неидентифицированными. Таким образом, из 20 объектов – элементов тестовой выборки, 13 объектов оказались классифицированы корректно. Следует также отметить, что среди неидентифицированных объектов не оказалось объектов класса «автомобили».

Во втором эксперименте данные об объектах тестовой выборки были добавлены к данным об объектах обучающей выборки, и с помощью D-AFC-TC-алгоритма было определено, что вся совокупность также «расслаивается» на 3 класса. При кластеризации данных о всей совокупности с помощью D-AFC(c)-алгоритма, распределение $R^*(X)$ по 3 полностью разделенным нечетким кластерам было получено при $\alpha = 0{,}9402$, причем некорректно классифицированными оказались 4 объекта, как и в первом эксперименте. На основании результатов кластеризации была сгенерирована система нечеткого вывода, и в процессе распознавания некорректно идентифицированными оказались 4 объекта, которые были некорректно классифицированными D-AFC(c)-алгоритмом, а неидентифицированных объектов не оказалось. Таким образом, на простом примере продемонстрирована эффективность предложенной методики дообучения системы нечеткого вывода.

Заключение

Предложенная методология построения системы нечеткого вывода позволяет генерировать систему нечеткого вывода в режиме времени, близком к реальному; кроме того, предложенный подход позволяет дообучать систему на основе данных о неидентифицированных объектах. Помимо точности и релевантности результатов классификации объектов, полученных с использованием построенной с помощью D-AFC(c)-алгоритма возможностной кластеризации системы нечеткого вывода, главным достоинством предложенного подхода к проектированию системы является возможность обработки данных в полностью автоматическом режиме.

Литература

1. Mamdani E.H. An experiment in linguistic synthesis with a fuzzy logic controller / E.H. Mamdani, S. Assilian // International Journal of Man-Machine Studies. – 1975. – Vol. 7. – P. 1-13.
2. Viattchenin D.A. A new heuristic algorithm of fuzzy clustering / Viattchenin D.A. // Control & Cybernetics. – 2004. – Vol. 33. – P. 323-340.
3. Борисов В.В. Нечеткие модели и сети / Борисов В.В., Круглов В.В., Федулов А.С. – М. : Горячая линия – Телеком, 2007. – 284 с.
4. Fuzzy Cluster Analysis: Methods for Classification, Data Analysis and Image Recognition / [F. Höppner, F. Klawonn, R. Kruse, T. Runkler]. – Chichester : Wiley Intersciences, 1999. – 289 p.
5. Sugeno M. A fuzzy-logic-based approach to qualitative modeling / M. Sugeno, T. Yasukawa // IEEE Transactions on Fuzzy Systems. – 1993. – Vol. 1. – P. 7-31.
6. Viattchenin D.A. Outlines for a new approach to generating fuzzy classification rules through clustering techniques / D.A. Viattchenin // Pattern Recognition and Information Processing: Proceedings of the 10th International Conference PRIP'2009 (Minsk, Belarus, May 19-21, 2009) / Ed. by V. Krasnoproshin, S. Ablameyko and R. Sadykhov. – Minsk : Publishing Center BSU, 2009. – P. 82-87.
7. Вятченин Д.А. О возможностной интерпретации значений принадлежности в методе нечеткой кластеризации, основанном на понятии распределения / Д.А. Вятченин // Вести Института современных знаний. – 2008. – № 3. – С. 85-90.
8. Viattchenin D.A. A direct algorithm of possibilistic clustering with partial supervision / D.A. Viattchenin // Journal of Automation, Mobile Robotics and Intelligent Systems. – 2007. – Vol. 1, № 3. – P. 29-38.

9. Viattchenin D.A. An outline for a heuristic approach to possibilistic clustering of the three-way data // Journal of Uncertain Systems. – 2009. – Vol. 3, № 1. – P. 64-80.
10. Дюбуа Д. Теория возможностей. Приложения к представлению знаний в информатике / Д. Дюбуа, А. Прад [пер. с фр.]. – М. : Радио и связь, 1990. – 288 с.
11. Кофман А. Введение в теорию нечетких множеств / Кофман А. [пер. с фр.; под ред. С.И. Травкина]. – М. : Радио и связь,1982. – 432 с.
12. Вятченин Д.А. Виды нечетких α-кластеров / Д.А. Вятченин // Вести Института современных знаний. – 2008. – № 4. – С. 95-101.
13. Гонсалес Р. Цифровая обработка изображений / Р. Гонсалес, Р. Вудс [пер. с англ]. – М. : Техносфера, 2006. – 1072 с.
14. Вятченин Д.А. Прямые алгоритмы нечеткой кластеризации, основанные на операции транзитивного замыкания и их применение к обнаружению аномальных наблюдений / Д.А. Вятченин // Искусственный интеллект. – 2007. – № 3. – С. 205-216.
15. Chiu S.L. Fuzzy model identification based on cluster estimation / S.L. Chiu // Journal of Intelligent and Fuzzy Systems. – 1994. – Vol. 2. – P. 267-278.
16. Hafiane A. A modified FCM with optimal Peano scans for image segmentation / A. Hafiane, B. Zavidovique, Chaudhuri S. // Proceedings of the 2005 IEEE International Conference on Image Processing ICIP'2005 (Genova, Italy, September 11 – 14, 2005). – Vol. 3. – Piscataway : IEEE Press, 2005. – P. 840-843.
17. Вятченин Д.А. Метод мягкой интерпретации результатов нечеткой кластеризации / Д.А. Вятченин // Таврический вестник информатики и математики. – 2008. – № 1. – С. 107-114.

Д.А. Вятченін, В.В. Старовойтов
Ідентифікація об'єктів за допомогою системи нечіткого висновку
У статті пропонується методологія ідентифікації об'єктів аерокосмічних зображеннях у режимі часу, близькому до реального, за допомогою механізму нечіткого висновку на прикладі системи нечіткого висновку типу Мамдані. Стисло викладається метод швидкого прототипування системи нечіткого висновку на основі результатів обробки даних об об'єктах навчальної виробки евристичним аморитмом можливістної кластеризації. Наводяться результати обчислювальних експериментів та сформульовані попередні висновки.

D.A. Viattchenin, V.V. Starovoitov
Objects Identification Through Fuzzy Inference System
The paper proposes a methodology to identify the objects on aerospace images in-time, close to the real, through the mechanism of fuzzy inference for the example of Mamdani's type fuzzy inference system. The method of rapid prototyping of a fuzzy inference system based on the result of the training data set processing by heuristic algorithm possibilistic clustering if described briefly. Results of numerical experiments are presented and preliminary conclusions are formulated.

Статья поступила в редакцию 31.05.2010.